



پیش‌بینی سود هر سهم: ترکیب شبکه‌های عصبی مصنوعی و الگوریتم بهینه‌سازی حرکت تجمعی ذرات

داریوش فروغی

استادیار حسابداری، دانشگاه اصفهان
D_Foroghi@Hotmail.Com

حیدر فروغ نژاد

دانشجوی دکترای مدیریت مالی، آموزشکده فنی و حرفه‌ای سما، دانشگاه آزاد اسلامی، واحد اندیشه (مسئول مکاتبات)
foroughnejad@yahoo.com

منوچهر میرزایی

کارشناسی ارشد حسابداری، دانشگاه اصفهان
ManochehrMirzaei@yahoo.com

تاریخ دریافت: ۹۲/۰۳/۲۵ تاریخ پذیرش: ۹۱/۱۱/۲۰

چکیده

انتظارات مربوط به سود اثرات قابل ملاحظه‌ای بر تصمیمات مدیران و سرمایه‌گذاران دارد. یکی از معیارهایی که امروزه به عنوان شاخص سودآوری شرکت‌ها مورد توجه قرار می‌گیرد، مفهوم سود هر سهم است. سود هر سهم آثار عمده‌ای بر قیمت سهام شرکت‌ها نیز دارد. از این‌رو پیش‌بینی سود هر سهم برای سرمایه‌گذاران و هم برای مدیران از اهمیت بسزایی برخوردار است. هدف از انجام این پژوهش، مدل‌بندی پیش‌بینی سود هر سهم شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران، با استفاده از ترکیب شبکه‌های عصبی مصنوعی و الگوریتم بهینه‌سازی حرکت تجمعی ذرات بر مبنای مدل‌های تک متغیره و چند متغیره است. بدین منظور از اطلاعات مربوط به ۱۱۴ شرکت از شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران، طی سال‌های ۱۳۸۰ تا ۱۳۸۹ استفاده شده است. نتایج این پژوهش نشان می‌دهد که مدل تک متغیره با دقت ۷۸.۵٪ و مدل چند متغیره با دقت ۹۱.۷٪ سود هر سهم را پیش‌بینی می‌نماید.

واژه‌های کلیدی: سود هر سهم، الگوریتم بهینه‌سازی حرکت تجمعی ذرات، متغیرهای بنیادی حسابداری، شبکه‌های عصبی مصنوعی.

۱- مقدمه

سرمایه‌گذاری در سهام و به طور کلی بازار سرمایه، یکی از گزینه‌های پرسود در دنیای تجارت است. یکی از معیارهای بسیار مهم جهت ارزیابی سرمایه‌گذاری در سهام که می‌تواند سرمایه‌گذاران را در اتخاذ تصمیمات بهینه هدایت نماید، مبلغ سود هر سهم است (لو و تیاگاراجان، ۱۹۹۳).

این اهمیت و حساسیت سود هر سهم باعث شده است که اولاً محاسبه و گزارش سود هر سهم واقعی و پیش‌بینی شده طبق قولانی بازار سرمایه بسیاری از کشورها الزامی گردد، ثانیاً مراجع تدوین-کننده استانداردهای حسابداری نیز الزامات معینی را در خصوص محاسبه و افشاری آن وضع نمایند تا سودمندی سود هر سهم را از طریق افزایش قابلیت مقایسه (بین شرکت‌ها و طی دوره‌های مختلف) و کاهش صلاحیت مدیریت ارتقاء دهن. علاوه بر این مفهوم سود هر سهم از جمله مفاهیمی است که سرمایه‌گذاران و تصمیم‌گیرندگان در حوزه مسائل مالی از آن به منظور تجزیه و تحلیل اطلاعات مالی و عملکرد شرکت‌ها استفاده می‌کنند (آباربانل و بوش، ۱۹۹۷).

بنابراین پیش‌بینی سود هر سهم یکی از دغدغه‌های مهم سرمایه‌گذاران خارجی و مدیران داخلی است. در خارج از شرکت، سرمایه‌گذاران از این پیش‌بینی‌ها به عنوان معیاری برای تشکیل پرتفوہای سرمایه‌گذاری سودآور استفاده می‌کنند و در داخل شرکت نیز مدیران جهت اتخاذ مجموعه‌ای از تصمیمات حیاتی نظری برآورده بودند (آنگ و همکاران، ۲۰۰۴). از اینرو دقت این پیش‌بینی‌ها هم برای مدیریت بهینه پرتفوہای سرمایه‌گذاری در بازارهای سرمایه و هم جهت تخصیص بهینه منابع در داخل شرکت، امری بسیار حیاتی است.

انتخاب متداول‌ترین پیش‌بینی هم به نوبه خود یکی از تصمیمات عمده‌ای است که سرمایه‌گذاران و مدیران با آن رو به رو هستند. در مطالعات فراوانی که در خصوص روش‌های متفاوت پیش‌بینی صورت گرفته است، این روش‌ها به شیوه‌های متعددی طبقه‌بندی شده‌اند. در یک طبقه‌بندی این مدل‌ها به خطی و غیرخطی تقسیم شده‌اند و طبقه‌بندی دیگر، آنها را به یک متغیره و چند متغیره تقسیم کرده است (کاو و پاری، ۲۰۰۹).

در رابطه با سود هر سهم، اکثر روش‌هایی که تاکنون مورد استفاده قرار گرفته، در دسته روش‌های خطی قرار می‌گیرند. لکن طیسال‌های اخیر مطالعاتی انجام شده که در آنها بر ماهیت غیرخطی بودن اطلاعات مالی تأکید شده است. به عنوان مثال کالن و همکاران (۱۹۹۶) بیان می‌کنند که سود هر سهم فصلی دارای ماهیت غیرخطی است و بنابراین استفاده از روش‌های خطی برای پیش‌بینی آن مناسب نخواهد بود. علاوه در ادبیات مربوط به پیش‌بینی سود هر سهم، بسیاری از تحقیقات به جای استفاده از

مدل‌های چند متغیره از مدل‌های یک متغیره استفاده کرده‌اند. مطالعه آباربانل و بوش(۱۹۹۷) نشان داد که در حوزه مدل‌های پیش‌بینی، مدل‌های چند متغیره نسبت به مدل‌های یک متغیره، کارایی بیشتری دارند. آنها بیان کردند که در رابطه با پیش‌بینی سود هر سهم، مجموعه‌های از متغیرهای حسابداری وجود دارند که می‌توانند دقت و صحت پیش‌بینی را افزایش دهند که این متغیرها را در ادبیات حسابداری، اصطلاحاً متغیرهای بنیادی حسابداری می‌نامند. چرا که این متغیرها می‌توانند در رابطه با رژیم‌های آتی اوراق بهادر و سودهای آتی علائم با اهمیتی فراهم کنند(آباربانل و بوش، ۱۹۹۷). در سال‌های اخیر شبکه‌های عصبی مصنوعی(ANN)^۱، به عنوان ابزاری متدالو جهت برآورد روابط غیرخطی مورد استفاده قرار گرفته است. اگرچه این شبکه‌ها دارای محسن زیادی در پیش‌بینی، طبقه-بندی و تکنیک‌های بهینه‌سازی هستند، اما دارای برخی عطف‌ها نظری گیر کردن شبکه در نقاط مینیمم محلی و سرعت پایین همگرایی محاسبات نیز می‌باشد. تأثیر منفی این قبیل نارسایی‌ها بر روایی و دقت پیش‌بینی سبب شد تا محققین الگوریتم‌های دیگری را جهت بهبود سرعت همگرایی محاسبات و دقت پیش‌بینی طراحی کنند(هایکین، ۱۹۹۸).

ترکیب دو روش محاسباتی(الگوریتم بهینه‌سازی حرکت تجمعی ذرات و شبکه‌های عصبی) در مسایل مالی، رویکرد جدیدی برای جستجوی بهترین متغیرها به منظور آموزش الگوی شبکه‌های عصبی است.

در مطالعه حاضر، الگوریتم بهینه‌سازی حرکت تجمعی ذرات برای بهینه‌سازی شبکه‌های عصبی جهت پیش‌بینی سود هر سهم مورد استفاده قرار می‌گیرد. همچنین جهت پیش‌بینی از مدل‌های یک متغیره و چند متغیره استفاده می‌شود. بدین منظور دقت پیش‌بینی مدل‌های غیرخطی یک متغیره و چند متغیره مورد مقایسه قرار خواهد گرفت.

۲- مبانی نظری و مروری بر پیشینه پژوهش

شبکه‌های عصبی مصنوعی

امروزه به موازات مدل‌های سری زمانی، دیدگاه دیگری در زمینه پیش‌بینی مطرح است. برتری این روش‌ها که به شبکه‌های عصبی مصنوعی معروف است، عدم نیاز به اجرای فرضیه‌های خاص در مورد رفتار متغیرها است. شبکه‌های عصبی مصنوعی، ساختاری شبیه به مغز انسان دارند. مغز انسان به عنوان یک سیستم پردازش اطلاعات از عناصر اصلی ساختاری به نام نرون تشکیل شده است. شبکه‌های عصبی مصنوعی نیز شامل مجموعه‌ای از نرون‌های به هم متصل می‌باشد که به هر مجموعه از این

نرون‌ها یک لایه گفته می‌شود. در نهایت برای ایجاد این لایه‌ها، نرون‌ها به وسیله توابع فعال سازی (محرك) به یکدیگر متصل می‌شوند(کاو و پاری، ۲۰۰۹).

یک شبکه عصبی به طور متداول از سه لایه ورودی، پنهان و خروجی تشکیل می‌شود. لایه ورودی فقط اطلاعات را دریافت می‌کند و مشابه متغیر مستقل عمل می‌کند. از این‌رو تعداد نرون‌های لایه ورودی بر اساس تعداد متغیرهای مستقل تعیین می‌شود. لایه خروجی نیز همانند متغیر وابسته عمل می‌کند و تعداد نرون‌های آن به تعداد متغیرهای وابسته بستگی دارد. بر خلاف لایه‌های ورودی و خروجی، لایه پنهان هیچ مفهومی را نشان نمی‌دهد و صرفاً یک نتیجه میانی در روند محاسبه ارزش خروجی است. شبکه‌های عصبی مصنوعی انواع مختلفی دارند اما یکی از پرکاربردترین نوع شبکه‌های عصبی، شبکه‌های عصبی پرسپترون چند لایه است. در این نوع از شبکه‌های عصبی، گره‌ها در لایه‌های متوالی قرار گرفته و ارتباط بین آنها یک طرفه است و زمانی که یک الگوی ورودی به شبکه وارد می‌شود، اولین لایه مقادیر خروجی خود را محاسبه می‌کند و در اختیار لایه بعدی قرار می‌دهد. لایه بعدی این اطلاعات را به عنوان ورودی دریافت کرده و مقادیر خروجی خود را به لایه بعدی منتقل می‌کند. در واقع در این نوع شبکه، هر گره به گره‌های لایه بعدی سینکال منتقل می‌کند(هایکین، ۱۹۹۸).

فرایند یادگیری در شبکه‌های عصبی

یکی از مهمترین ویژگی‌های شبکه‌های عصبی مصنوعی که عملکرد آن را به انسان نزدیک‌تر می‌کند، قدرت یادگیری است. در شبکه‌های عصبی از آن جهت به یادگیری نیاز است که ارتباط میان ورودی‌ها و خروجی‌ها به طور دقیق و کامل مشخص نیست. از آنجا که تجربه‌ها در طول زمان حاصل می‌شود، لذا میزان یادگیری به درجه کامل بودن اطلاعات قبلی بستگی دارد. شبکه‌های عصبی از اشتباه‌هایی که مرتکب می‌شوند، می‌آموزند(شانکر و همکاران، ۱۹۹۶). فرایند یادگیری یا آموزش در شبکه‌های عصبی، معمولاً طی سه مرحله زیر صورت می‌گیرد:

- محاسبه برون دادها
- مقایسه برون دادها با پاسخ‌های مطلوب و مورد نظر
- تعدل وزن‌ها و تکرار فرایند

فرایند یادگیری با انتخاب تصادفی وزن‌ها آغاز می‌شود. تفاوت میان برونداد واقعی و برونداد مورد نظر دلتا نامیده می‌شود. در اینجا هدف حداقل کردن دلتا یا حتی به صفر رساندن آن است. کاهش دلتا از طریق ایجاد تغییرات تدریجی در وزن‌ها انجام می‌شود. پردازش اطلاعات با استفاده از شبکه‌های عصبی، شامل شناسایی و تجزیه و تحلیل الگوهای فعالیت نیز هست. یکی از ویژگی‌های مشترک

شبکه‌های عصبی، این است که می‌توانند علی‌رغم نداشتن دانش واضح از قواعد، داده‌های ورودی را طبقه‌بندی کنند و برای به حافظه سپردن دسته‌ها از الگوی‌های وزنی اختیاری استفاده کنند. در طول مراحل یادگیری، وزن ارتباطی در پاسخ به داده‌های آموزشی که به سیستم ارائه می‌شود، تغییر می‌کند (هایکین، ۱۹۹۸). شبکه‌های عصبی مختلف، خطا را به شیوه‌های مختلف محاسبه می‌کنند. این امر به الگوریتم مورد استفاده برای یادگیری شبکه بستگی دارد. در فرایند آموزش شبکه‌های عصبی، مجموعه داده‌ها به دو دسته تقسیم می‌شوند: داده‌های آزمایشی و داده‌های آموزشی. داده‌های آموزشی برای بالا بردن توان یادگیری وارد شبکه می‌شوند و شبکه باید وزن‌های ارتباطی را از الگوهای آموزشی موجود فرا گیرد. عملکرد شبکه از طریق به هنگام سازی وزن‌ها بهبود می‌یابد. سپس کیفیت و توانایی شبکه با اعمال داده‌های آزمایشی برآورد می‌شود (هایکین، ۱۹۹۸).

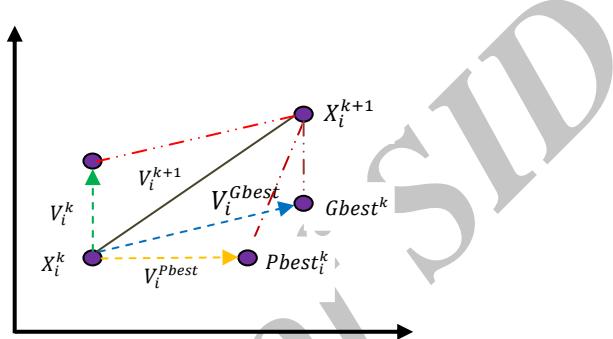
در این مطالعه از ۵۰ درصد از داده‌های جمع‌آوری شده به عنوان داده‌های آموزشی و از ۵۰ درصد مابقی آن، به عنوان داده‌های آزمایشی استفاده شده است. همچنین به منظور آموزش شبکه از الگوریتم بهینه‌سازی حرکت تجمعی ذرات استفاده شده است.

الگوریتم بهینه‌سازی حرکت تجمعی ذرات

در سال‌های اخیر با توجه به محدودیت‌های موجود در روش‌های ریاضی، پژوهش‌های بسیاری در زمینه استفاده از الگوریتم‌های تکاملی در جهت بهینه‌سازی انجام شده است. یکی از کاراترین تکنیک‌های مورد استفاده در این زمینه، تکنیک بهینه‌سازی حرکت تجمعی ذرات (PSO) است. الگوریتم PSO اولین بار توسط کندی و ابرهارت (۱۹۹۵) به کار برده شد. این الگوریتم الهام گرفته از پرواز هم‌مان پرنده‌گان، شناخته جمعی ماهی‌ها و زندگی اجتماعی آنها می‌باشد که با استفاده از یک سری روابط ساده ترکیب‌بندی شده است (کندی و ابرهارت، ۱۹۹۵). جمعیت (حرکت تجمعی) در PSO، شامل مجموعه‌ای از اعضاء است که به هر عضو داخل جمعیت، یک ذره^۱ گفته می‌شود. در این تکنیک از مفهوم جانمایی همسایگی جی‌بست^۲ استفاده می‌شود. یعنی هر ذره بهترین موقعیت قبلی خود و بهترین موقعیت قبلی هر یک از ذرات موجود در جمعیت را به خاطر می‌آورد و به عبارت دیگر هر ذره در جهت بهترین موقعیت قبلی خود و به سمت بهترین ذره در حرکت است (کندی و ابرهارت، ۱۹۹۵).

کندی در سال ۱۹۹۸ شرح داد که در PSO، هر ذره نماینده یک جواب ممکن است که به صورت تصادفی در فضای مسئله حرکت می‌کند. تغییر مکان هر ذره در فضای جستجو، تحت تأثیر تجربه و دانش خود و همسایگانش است. بنابراین موقعیت ذرات دیگر گروه بر چگونگی جستجوی یک ذره اثر می‌گذارد. نتیجه مدل‌سازی این رفتار اجتماعی، فرایند جستجویی است که در آن ذرات به سمت نواحی

مناسب میل می‌کنند. ذرات در گروه از یکدیگر می‌آموزند و بر مبنای دانش به دست آمده، به سمت بهترین همسایگان خود حرکت می‌کنند(پلی و همکاران، ۲۰۰۷). در واقع اساس کار PSO بر این اصل استوار است که در هر لحظه هر ذره مکان خود را در فضای جستجو با توجه به بهترین مکانی که تا کنون در آن قرار گرفته و بهترین مکانی که در همسایگی اش وجود دارد، تنظیم می‌کند(کندی و ابرهارت، ۱۹۹۵). نگاره(۱) فرایند تغییر موقعیت ذره‌ها را در الگوریتم PSO نشان می‌دهد.



نگاره ۱: فرایند تغییر موقعیت ذرات در الگوریتم بهینه سازی حرکت تجمعی ذرات.

فرض کنید یک فضای D بعدی وجود دارد و α امین ذره از گروه می‌تواند با یک بردار سرعت و یک بردار موقعیت نشان داده شود. تغییر موقعیت هر ذره، با تغییر در ساختار موقعیت و سرعت قبلی امکان‌پذیر است. هر ذره اطلاعاتی شامل بهترین مقداری را که تا کنون به آن رسیده($Pbest$)^۶ و موقعیت X_i را داراست. این اطلاعات از مقایسه تلاش‌هایی که هر ذره برای یافتن بهترین جواب انجام می‌دهد، به دست می‌آید. همچنین هر ذره بهترین جوابی که تا کنون از مقدار $Pbest$ ها در گروه به دست آمده است را می‌شناسد($Gbest$)^۷. هر ذره برای رسیدن به بهترین جواب سعی می‌کند که موقعیت خود را با استفاده از اطلاعات زیر تغییر دهد:

موقعیت کنونی X_i ، سرعت کنونی V_i ، فاصله بین موقعیت کنونی و $Pbest$ و فاصله بین موقعیت کنونی و $Gbest$. بدین ترتیب سرعت ذره به صورت زیر تغییر می‌کند:

$$Y_i^{k+1} = W \cdot V_i^k + C_1 r_1 (Pbest_i - X_i^k) + C_2 r_2 (Gbest_i - X_i^k) \quad \text{رابطه ۱}$$

در رابطه فوق:

سرعت هر ذره در تکرار k ام، W پارامتر وزنی، C_1 و C_2 فاکتور وزنی، r_1 و r_2 عدد تصادفی در بازه $[0, 1]$ ، X_i^k موقعیت هر ذره در تکرار k ام، P_{best_i} برابر P_{best} در ذره i و G_{best} در گروه است(پلی و همکاران، ۲۰۰۷). موقعیت هر ذره نیز بر اساس رابطه زیر تعیین می‌شود:

$$X_i^{k+1} = X_i^k + V_i^{k+1} \quad \text{رابطه ۲}$$

پارامترهای PSO

پارامتر وزنی W در رابطه (۱) برای تضمین همگرایی در PSO و همچنین کنترل تأثیر سوابق سرعت‌های پیشین بر سرعت‌های جاری مورد استفاده قرار می‌گیرد. یک مقدار مناسب پارامتر وزنی، عموماً تعادلی را بین قابلیت جستجو کلی^۸ و جستجوی محلی^۹ ایجاد می‌کند(کندی و ابرهارت، ۱۹۹۵). با انتخاب مناسب مقدار پارامتر وزنی، میزان تکرار برای یافتن جواب بهینه کاهش می‌یابد. ضریب ثابت اینرسی بزرگتر از یک، هر چند سبب می‌شود فضای جستجوی الگوریتم وسیع‌تر گردد، اما الگوریتم را ناپایدار می‌کند. زیرا اثر سرعت پیشین را افزایش می‌دهد. در ابتدا مقدار W ثابت در نظر گرفته می‌شد، اما بعدها مطالعات ابرهارت در سال‌های ۱۹۹۸ و ۱۹۹۹ در این زمینه منجر به تغییر شگرفی در الگوریتم PSO شد. آنها پارامتر وزنی را به صورت خطی از مقدار بیشینه‌ای چون WMAX تا مقدار حداقل آن WMIN، به صورت زیر تغییر دادند:

$$W = W_{MAX} - \frac{W_{MAX} - W_{MIN}}{iter_{MAX}} \times iter \quad \text{رابطه ۳}$$

در رابطه مذکور:

W_{MAX} وزن ابتدایی، W_{MIN} وزن انتهایی، $iter_{MAX}$ شماره تکرار و $iter$ بزرگترین شماره تکرار است(پلی و همکاران، ۲۰۰۷).

پارامترهای C_1 و C_2 در رابطه (۳) برای همگرایی PSO چندان بحرانی نیستند. مقدار مناسب ممکن است جواب را زودتر همگرا کند و از احتمال گیر افتادن در نقطه مینیمم محلی جلوگیری می‌کند. در ابتدا مقدار $C_2 = 2C_1 = 0.5$ پیشنهاد شد، اما مطالعات بعدی نشان داد که $C_2 = C_1 = 0.5$ می‌تواند در رسیدن به جواب بهینه مفیدتر باشد. در حالت کلی C_1 و C_2 می‌توانند متفاوت انتخاب شوند اما شرط $C_1 + C_2 < 4$ بایستی همواره برقرار باشد(کندی و ابرهارت، ۱۹۹۵). پارامترهای r_1 و r_2 برای حفظ تنوع و گوناگونی در گروه به کار می‌روند. مقدار مناسب این پارامترها، در یکنواختی جواب‌ها تأثیرگذار است و این پارامتر به صورت تصادفی در بازه $[0, 1]$ انتخاب می‌شوند. این مقادیر به ذرات این اجزا را می‌دهند که در گام‌های تصادفی، در محدوده بین G_{best} و P_{best} حرکت کنند(پلی و همکاران، ۲۰۰۷).

با توجه به اهمیت سود هر سهم، پژوهش‌های بسیاری پیرامون آن انجام شده است بعلاوه طی سال‌های اخیر مطالعات بسیاری نیز در زمینه استفاده از سیستم‌های خبره در حوزه حسابداری و مالی صورت گرفته است. نمونه‌هایی از این مطالعات شامل موارد زیر است:

لو و تیاگاراجان(۱۹۹۳) در مطالعه‌ای به بررسی قدرت تبیین متغیرهای بنیادی حسابداری پرداختند. آنها از طریق تجزیه و تحلیل صورت‌های مالی، متغیرهایی از قبیل موجودی کالا، مخارج سرمایه‌ای و سود ناویزه را به عنوان متغیرهای بنیادی حسابداری معرفی کردند. نتایج این پژوهش نشان داد که لحاظ نمودن متغیرهای بنیادی حسابداری در مدل‌های رگرسیون خطی، قدرت تبیین کنندگی این مدل‌ها را در پیش‌بینی سودهای آتی افزایش می‌دهد(لو و تیاگاراجان، ۱۹۹۳).

کالن و همکاران(۱۹۹۶) در مطالعه خود به مقایسه توانایی پیش‌بینی مدل‌های سری زمانی خطی یک متغیره(آریما)^{۱۰} و شبکه‌های عصبی مصنوعی جهت پیش‌بینی سود هر سهم پرداختند. نتایج نشان داد که مدل‌های سری زمانی و یک متغیره براون-رازف و گریفین-واتس جهت پیش‌بینی سود هر سهم، نسبت به شبکه‌های عصبی مصنوعی از دقت پیش‌بینی بیشتری برخوردار است(کالن و همکاران، ۱۹۹۶).

آباربانل و بوش(۱۹۹۷) در پژوهش خود تأثیر متغیرهای بنیادی حسابداری را در پیش‌بینی سود-های آتی هر سهم مورد بررسی قرار دادند. آنها با استفاده از یک مدل رگرسیون خطی نشان دادند که تغییرات جاری در متغیرهای بنیادی حسابداری حاوی اطلاعاتی در مورد تغییرات سود هر سهم آتی است. به طور کلی نتایج این پژوهش، وجود رابطه معنادار بین متغیرهای بنیادی حسابداری و سودهای هر سهم آتی را اثبات کرد(آباربانل و بوش، ۱۹۹۷).

ژانگ و همکاران(۲۰۰۴) در پژوهش خود، دقت پیش‌بینی مدل‌های خطی یک متغیره و چند متغیره را با دقت شبکه‌های عصبی در پیش‌بینی سود هر سهم مقایسه کردند. آنها در مدل‌های چند متغیره خود از متغیرهای بنیادی حسابداری استفاده کردند. یافته‌های این مطالعه نشان داد که کاربرد رویکرد شبکه‌های عصبی شامل متغیرهای بنیادی حسابداری، نسبت به مدل‌های خطی از دقت پیش-بینی بالاتری برخوردار است(ژانگ و همکاران، ۲۰۰۴).

کاو و پاری(۲۰۰۹) در مطالعه‌ای، دقت پیش‌بینی روش‌های خطی یک متغیره و چند متغیره را با شبکه‌های عصبی در پیش‌بینی سود هر سهم مورد مقایسه قرار دادند. آنها در مدل شبکه‌های عصبی جهت تخمین وزن‌ها از الگوریتم پس انتشار خطأ^{۱۱} و الگوریتم ژنتیک^{۱۲} استفاده کردند. نتایج بررسی‌ها نشان داد که مدل شبکه‌های عصبی مبتنی بر الگوریتم ژنتیک که شامل متغیرهای بنیادی حسابداری است، نسبت به مدل شبکه‌های عصبی مبتنی بر الگوریتم پس انتشار خطأ و مدل‌های خطی، از دقت پیش‌بینی بیشتری برخوردار است(کاو و پاری، ۲۰۰۹).

اعتمادی و همکاران(۲۰۰۹) در مطالعه خود، جهت پیش‌بینی ورشکستگی شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران، از رویکرد برنامه‌نویسی ژنتیک^{۱۳} و تحلیل ممیزی چندگانه استفاده کردند. یافته‌های آنان نشان داد که رویکرد برنامه نویسی ژنتیک، نسبت به تحلیل ممیزی چندگانه از دقت پیش‌بینی بالاتری برخوردار است(اعتمادی و همکاران، ۲۰۰۹).

هداوندی و همکاران(۲۰۱۰) در پژوهشی از شبکه‌های عصبی مصنوعی و سیستم‌های فازی- ژنتیک^{۱۴}، به منظور پیش‌بینی قیمت سهام استفاده کردند. یافته‌های تجربی آنان حاکی از آن است که این روش نسبت به روش‌هایی که در سایر مطالعات مربوط به پیش‌بینی قیمت سهام مورد استفاده قرار گرفته است، عملکرد بهتری دارد و می‌تواند به عنوان ابزاری جهت حل مسائل مربوط به پیش‌بینی قیمت سهام مورد استفاده قرار گیرد(هداوندی و همکاران، ۲۰۱۰).

گل‌مکانی و فاضل(۲۰۱۱) روشی را جهت حل و بسط مدل انتخاب پرتفوی میانگین-واریانس مارکویتز ارائه دادند. در این راستا آنها به مقایسه عملکرد دو الگوریتم بهینه‌سازی حرکت تجمعی ذرات و الگوریتم ژنتیک پرداختند. نتایج بررسی‌های آنان نشان داد که در انتخاب یک پرتفوی بهینه، الگوریتم بهینه‌سازی حرکت تجمعی ذرات عملکرد بهتری دارد(گل‌مکانی و فاضل، ۲۰۱۱).

هسیو و همکاران(۲۰۱۱) با استفاده از الگوریتم بهینه‌سازی حرکت تجمعی ذرات، یک استراتژی کارا را جهت انجام معاملات مربوط به صندوق‌های سرمایه‌گذاری معرفی کردند. نتایج این مطالعه نشان داد که استراتژی یاد شده از قابلیت بالایی برخوردار بوده و با تحمل کمترین ریسک، بالاترین بازده ممکن را عاید می‌کند(هسیو و همکاران، ۲۰۱۱).

دنگ و همکاران(۲۰۱۲) به بررسی و مقایسه عملکرد دو الگوریتم بهینه‌سازی حرکت تجمعی ذرات و الگوریتم ژنتیک در انتخاب یک پرتفوی کارا بر اساس مدل انتخاب پرتفوی مارکوویتز پرداختند. بررسی‌های آنها نشان داد که در تمامی موارد، الگوریتم بهینه‌سازی حرکت تجمعی ذرات از کارایی بیشتری برخوردار است(دنگ و همکاران، ۲۰۱۲).

در ایران هیچ مطالعه‌ای در رابطه با پیش‌بینی سود هر سهم با استفاده از سیستم‌های خبره انجام نشده است. اما پژوهش‌های بسیاری در خصوص کاربرد این سیستم‌ها در سایر حوزه‌های مالی، انجام شده که مهترین آنها به شرح زیر است:

ستایش و همکاران(۳۸۸) جهت پیش‌بینی و تعیین ساختار بهینه سرمایه شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران در مطالعه خود از الگوریتم ژنتیک استفاده کردند. در این مطالعه مدل‌سازی داده‌های ورودی و خروجی با استفاده از رگرسیون بردار پشتیبان و تعیین ساختار بهینه سرمایه با استفاده از الگوریتم ژنتیک صورت گرفته است. نتایج این پژوهش نشان داد که بیشترین

سودآوری در ازای استفاده کمتر از اهرم مالی حاصل می‌شود که این نتیجه تأیید کننده وجود رابطه منفی بین ساختار سرمایه و نرخ بازده دارایی‌ها است (ستایش و همکاران، ۱۳۸۸).

عرب‌مازار و قاسمی (۱۳۸۸) در مطالعه خود از ترکیبی از شبکه‌های عصبی و الگوریتم ژنتیک به منظور بررسی قیمت‌گذاری عرضه‌های عمومی اولیه سهام شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران استفاده کردند. نتایج این بررسی‌ها نشان داد که ترکیب شبکه‌های عصبی مصنوعی با الگوریتم ژنتیک به منظور تعیین متغیرهای بهینه، قدرت پیش‌بینی را به طور محسوسی افزایش می‌دهد (عرب‌مازار و قاسمی، ۱۳۸۸).

راعی و علی‌بیکی (۱۳۸۹) در مطالعه خود با استفاده از الگوریتم بهینه‌سازی حرکت تجمعی ذرات به حل مسئله بهینه‌سازی پرتفوی مارکوویتز (مدل واریانس- میانگین) پرداختند. آنها با استفاده از اطلاعات مربوط به قیمت ۲۰ سهم پذیرفته شده در بورس اوراق بهادار تهران، مرز کارای سرمایه‌گذاری را رسم کردند. نتایج پژوهش آنها نشان می‌دهد که روش بهینه‌سازی حرکت تجمعی ذرات، در بهینه‌سازی پرتفوی سهام با وجود محدودیت‌های بازار موفق است (راعی و علی‌بیکی، ۱۳۸۹).

دموری و همکاران (۱۳۹۰) در مطالعه خود به بررسی و مقایسه توانایی الگوریتم بهینه‌سازی حرکت تجمعی ذرات با مدل‌های سنتی در پیش‌بینی شاخص کل قیمت سهام در بورس اوراق بهادار تهران پرداختند. نتایج مطالعه آنها نشان داد که الگوریتم بهینه‌سازی حرکت تجمعی ذرات در مقایسه با روش‌های سنتی نظری ARIMA، از دقت پیش‌بینی بالاتری برخوردار است (دموری و همکاران، ۱۳۹۰).

۳- فرضیه‌های پژوهش

با توجه به مطالبی که در بخش مقدمه تشریح شد، این مقاله دارای دو فرضیه اصلی به شرح زیر است:

- پیش‌بینی سود هر سهم شرکت‌های پذیرفته شده در بورس اوراق بهادار با استفاده از ترکیب شبکه‌های عصبی و الگوریتم بهینه‌سازی حرکت تجمعی ذرات امکان پذیر است.
- استفاده از متغیرهای بنیادی حسابداری در مدل‌های غیرخطی چند متغیره جهت پیش‌بینی سود هر سهم، دقت پیش‌بینی را افزایش می‌دهد.

۴- روش‌شناسی پژوهش

روش این پژوهش توصیفی از نوع همبستگی است. در انجام این پژوهش پس از نرمال‌سازی داده‌ها و بهینه‌سازی شبکه‌های عصبی با استفاده از الگوریتم بهینه‌سازی حرکت تجمعی ذرات، اقدام به پیش‌بینی سود هر سهم شرکت‌های منتخب شده است.

نرمال‌سازی داده‌ها که به مفهوم پیش‌پردازش و پس‌پردازش داده‌ها است، سبب بهبود عملکرد شبکه می‌شود. پیش‌پردازش داده‌ها، که معمولاً قبل از آموزش شبکه صورت می‌گیرد، به معنی انجام تبدیل‌هایی بر روی داده‌های ورودی و خروجی شبکه، به منظور بیرون کشیدن ویژگی‌ها از درون ورودی‌ها و تبدیل خروجی به شکل قابل درک‌تر برای شبکه است. پس از آموزش و استخراج نتایج از شبکه، خروجی‌های شبکه نیز به شکل اولیه خود تبدیل می‌شوند که به آن پس‌پردازش گفته می‌شود(شانکر و همکاران، ۱۹۹۶).

روش‌های گوناگونی برای برای نرمال‌سازی داده‌ها وجود دارد؛ یکی از روش‌های معمول در این زمینه، نرمال‌سازی آماری است. در این روش، میانگین داده‌ها صفر و انحراف معیار آنها برابر یک خواهد شد. بدین منظور از رابطه زیر استفاده می‌شود:

$$X_n = (X_0 - \bar{X})/S \quad \text{رابطه ۴}$$

که در آن X_n ، X_0 و \bar{X} به ترتیب داده‌های نرمال شده، داده‌های اصلی و میانگین داده‌ها و S انحراف معیار داده‌ها است(هایکین، ۱۹۹۸). در این مطالعه از این روش برای نرمال‌سازی داده‌ها استفاده شده است.

به منظور مقایسه قدرت پیش‌بینی و انتخاب بهترین روش‌های پیش‌بینی، معمولاً داده‌ها را به دو مجموعه مجزا تقسیم می‌کنند. بخش اول مجموعه داده‌های آموزش و بخش دوم مجموعه داده‌های آزمون است. ابتدا ضرایب مدل با استفاده از داده‌های مجموعه اول برآورد می‌شود و سپس با استفاده از داده‌های مجموعه دوم قدرت پیش‌بینی مدل خارج از مجموعه^{۱۵} داده‌های آموزش ارزیابی می‌شود. هدف نهایی حداقل کردن خطای پیش‌بینی در مجموعه داده‌های آزمون است. با توجه به اینکه قلمرو زمانی پژوهش حاضر یک دوره ده ساله(از سال ۱۳۸۰ تا سال ۱۳۸۹) می‌باشد، لذا برای هر شرکت عضو نمونه آماری، تعداد ۱۰ سود هر سهم مشاهده شده وجود دارد. لذا از ۵۰ درصد داده‌ها به عنوان داده‌های آموزش و از ۵۰ درصد مابقی به عنوان داده‌های آزمون استفاده شده است. بر این اساس هر یک از مدل‌های پیش‌بینی ۵ مرتبه و با افق زمانی یک ساله(از سال ۱۳۸۵ تا ۱۳۸۹) و روش برآورد چرخشی^{۱۶} برآورد می‌شوند. بدین معنی که به عنوان مثال برای پیش‌بینی سود هر سهم سال ۱۳۸۵ از داده‌های مربوطه طی سال‌های ۱۳۸۰ تا ۱۳۸۴ و برای پیش‌بینی سود هر سهم سال ۱۳۸۶ از داده‌های مربوطه طی سال‌های ۱۳۸۰ تا ۱۳۸۵ استفاده می‌شود. با توجه به مطالب مذکور معیارهای اندازه‌گیری خطای پیش‌بینی در این مطالعه به شرح زیر است:

- میانگین قدر مطلق خطای

$$\text{MAPE} = \frac{1}{5} \sum_{t=85}^{t=89} \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| \quad \text{رابطه ۵}$$

• میانگین مجدور خطا

$$MSE = \frac{1}{5} \sum_{t=85}^{89} \left(\frac{Y_t - \bar{Y}_t}{Y_t} \right)^2 \quad \text{رابطه ۶}$$

در روابط فوق \bar{Y} بیانگر مقدار واقعی، \tilde{Y} مقدار پیش‌بینی شده، N تعداد مقادیر واقعی و t سال مالی است.

از آنجا که در این پژوهش به پیش‌بینی سود هر سهم در بازار سرمایه پرداخته می‌شود و به این دلیل که اطلاعات لازم در ارتباط با پیش‌بینی سود هر سهم شرکت‌ها به صورت مدون و با درجه اطمینان بالا، تنها در بورس اوراق بهادار تهران موجود است، جامعه آماری این پژوهش منحصر به شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران طی دوره زمانی ۱۳۸۰ تا ۱۳۸۹ می‌باشد. در این پژوهش برای انتخاب اعضای نمونه از روش حذف سیستماتیک استفاده شده است، به این ترتیب که شرکت‌های دارای ویژگی‌های زیر به عنوان نمونه انتخاب شده‌اند:

- به منظور قابل مقایسه بودن اطلاعات، قبل از سال ۱۳۸۰ در بورس اوراق بهادار تهران پذیرفته شده باشند. سال مالی آنها منتهی به پایان اسفند ماه هر سال باشد و طی دوره مورد بررسی سال مالی خود را تغییر نداده باشند.
- به منظور همگن بودن اطلاعات، فعالیت آنها تولیدی باشد.
- تمام اطلاعات مورد نیاز برای انجام پژوهش را داشته باشند.

با در نظر گرفتن شرایط مذکور تعداد ۱۱۴ شرکت به عنوان نمونه انتخاب شدند.

در این پژوهش سود هر سهم، به عنوان متغیر وابسته در انظر گرفته شده و متغیرهای مستقل بر اساس مطالعات و پژوهش‌های انجام شده در این زمینه انتخاب شده است. از آنجا که در این پژوهش یک مدل یک متغیره و یک مدل چند متغیره به کار گرفته شده، لازم است متغیرهای مستقل هر دسته از این مدل‌ها به طور جداگانه معرفی شوند. در مدل‌های یک متغیره سود هر سهم سال قبل به عنوان متغیر مستقل و در مدل چند متغیره علاوه بر سود هر سهم سال قبل، از هفت متغیر دیگر نیز استفاده شده است که بر اساس مطالعه لو و تیاگاراجان (۱۹۹۳) عبارتند از:

- نسبت موجودی کالا به تعداد سهام عادی در پایان سال مالی (INV).
- نسبت حساب‌های دریافتی به تعداد سهام عادی در پایان سال مالی (AR).
- نسبت خالص اموال، ماشین آلات و تجهیزات به تعداد سهام عادی در پایان سال مالی (CAPX).
- نسبت سود ناخالص به تعداد سهام عادی در پایان سال مالی (GM).
- نسبت هزینه‌های عمومی، اداری و فروش به تعداد سهام عادی در پایان سال مالی (SA).

- نرخ مؤثر مالیات در پایان سال مالی که از تقسیم مالیات بر سود قبل از مالیات به دستمی آید.(ETR).

- بهره‌وری نیروی کار در پایان سال مالیکه برابر است با لگاریتم نسبت فروش به تعداد کارکنان(LFP) (لو و تیاگاراجان، ۱۹۹۳).

در این پژوهش داده‌های مربوط به متغیرهای پژوهش با استفاده از متن صورت‌های مالی، یادداشت‌های همراه آنها و نیز اطلاعات موجود در نرم افزارهای اطلاعاتی تدبیرپرداز و رهآورد نوین و تارنما و کتابخانه رسمی سازمان بورس و اوراق بهادار جمع‌آوری شده‌اند. همچنین به منظور طراحی مدل شبکه‌های عصبی و برآورد آن از نرم افزار MATLAB نسخه ۷.۹ استفاده شده است.

۵- مدل‌های پژوهش

با توجه به اینکه دوره زمانی این پژوهش یک دوره ده ساله از سال ۱۳۸۰ تا ۱۳۸۹ می‌باشد، و در هر دوره پیش‌بینی سود هر سهم برای ادوار زمانی سالانه انجام می‌شود، لذا در این پژوهش ده دوره زمانی یک ساله وجود خواهد داشت که مدل‌های مطالعه بر این مبنای تدوین شده‌اند.

۱. مدل شبکه عصبی یک متغیره آموزش دیده با الگوریتم بهینه‌سازی حرکت تجمعی ذرات که بر مبنای متغیر سودواقعی هر سهم در سال قبل بنای شده است(UPSO).

$$UPSO: E(Y_t) = \sum_{j=1}^n \alpha_i \text{logsig}(\beta_{0j} + \beta_{ij} Y_{t-1}) \quad \text{رابطه ۷}$$

در رابطه مذکور:

E(Y_t): سود هر سهم مورد انتظار در زمان t.

Y_{t-1}: سود واقعی هر سهم در زمان t - 1.

α_i : اتصال وزنی i امین متغیر لایه پنهان با متغیر خروجی شبکه عصبی.

β_{ij} : اتصال وزنی i امین ورودی به j امین متغیر لایه پنهان شبکه عصبی.

β_{0j} : میزان انحراف j امین متغیر لایه پنهان شبکه عصبی.

sig(n): در این مدل ازتابع سیگموئید استفاده شده که به شرح تعریف می‌شود:

$$\text{sig}(n) = \frac{1}{1+e^{-n}} \quad \text{رابطه ۸}$$

که در آن $e^{-n} = e^{(-n)}$ می‌باشد.

۲. مدل شبکه عصبی چند متغیره آموزش دیده با الگوریتم بهینه‌سازی حرکت تجمعی ذرات که متغیرهای بنیادی حسابداری در آن لحاظ شده است.(MPSO).

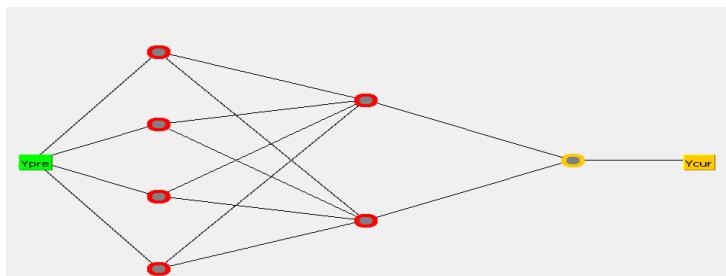
$$\text{MPSO: } E(Y_t) = \sum_{j=1}^n \alpha_j \text{logsig}(\beta_{0j} + \beta_{1j}Y_{t-1} + \beta_{2j}\text{INV}_{t-1}\delta + \beta_{3j}\text{AR}_{t-1} + \beta_{4j}\text{CAPX}_{t-1} + \beta_{5j}\text{GM}_{t-1} + \beta_{6j}\text{SA}_{t-1} \\ + \beta_{7j}\text{ETR}_{t-1} + \beta_{8j}\text{LFP}_{t-1})$$

شبکه عصبی طراحی و بهینه سازی شده توسط الگوریتم بهینه‌سازی حرکت تجمعی ذرات در طراحی شبکه‌های عصبی علاوه بر انتخاب مجموعه‌ای از متغیرهای ورودی باید ساختار شبکه‌ای که منجر به بهترین پیش‌بینی می‌شود، شناسایی گردد. تغییر ساختمان یک شبکه حتی بدون تغییر متغیرهای ورودی و خروجی و اندازه نمونه، می‌تواند پیش‌بینی‌های انجام شده را به طور اساسی تغییر دهد.

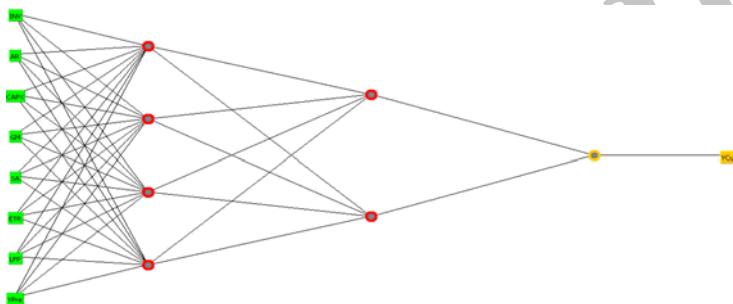
شبکه‌های عصبی پرسپترون چند لایه پرکاربردترین نوع شبکه‌های عصبی هستند که در اغلب پژوهش‌ها مورد استفاده قرار گرفته‌اند، در این مطالعه نیز پس از انجام بررسی‌های لازم و مقایسه شبکه‌های عصبی متنوع، از این نوع شبکه عصبی استفاده شد. پس از تعیین نوع شبکه و روش آموزش باید تعداد گره‌ها یا نرون‌های ورودی، تعداد لایه‌ها و گره‌های مخفی و تعداد گره‌های خروجی تعیین شود. تعداد ورودی‌ها از اهمیت خاصی برخوردار است، زیرا هر الگوی ورودی اطلاعات مهمی در مورد ساختار خود همبسته و پیچیده داده‌ها را شامل می‌شود.

در این پژوهش تعداد گره‌های ورودی دقیقاً به اندازه متغیرهای مستقل در نظر گرفته شده است. یعنی برای مدل یک متغیره یک گره و برای مدل چند متغیره هشت گره در نظر گرفته شده است. با توجه به این که متغیر وابسته این مطالعه سود هر سهم می‌باشد، لذا تعداد گره خروجی یک گره است. لایه‌ها و گره‌های پنهان نیز نقش مهمی در عملکرد دقیق شبکه‌های عصبی ایفا می‌کنند. گره‌های لایه‌های پنهان به شبکه عصبی اجازه می‌دهد تا خصوصیات داده‌ها را کشف و شناسایی نمایند و بدین وسیله نگاشت‌های پیچیده غیرخطی را بین متغیرهای ورودی و خروجی برقرار کنند.

از لحاظ تئوریک، شبکه‌های عصبی می‌توانند دقت دلخواه را برای تقریب توابع با استفاده از تعداد کافی گره در لایه یا لایه‌های مخفی به دست آورند. در این پژوهش در هر دو مدل یک متغیره و چند متغیره از دو لایه پنهان با چهار گره در لایه نخست و دو گره در لایه دوم استفاده شده است. توابع فعال‌سازی، ارتباط بین ورودی و خروجی یک گره و یک شبکه را مشخص می‌کنند. این توابع درجه‌ای از خطی بودن را به شبکه تزریق می‌نمایند. برای لایه میانی، در این مطالعه ازتابع سیگموئیدی و برای لایه خروجی از یک تابع خطی استفاده شده است. نگاره‌های (۲) و (۳) شبکه‌های عصبی طراحی شده جهت آزمون فرضیه‌ها را نشان می‌دهد.



نگاره ۲) شبکه عصبی مربوط به مدل تک متغیره



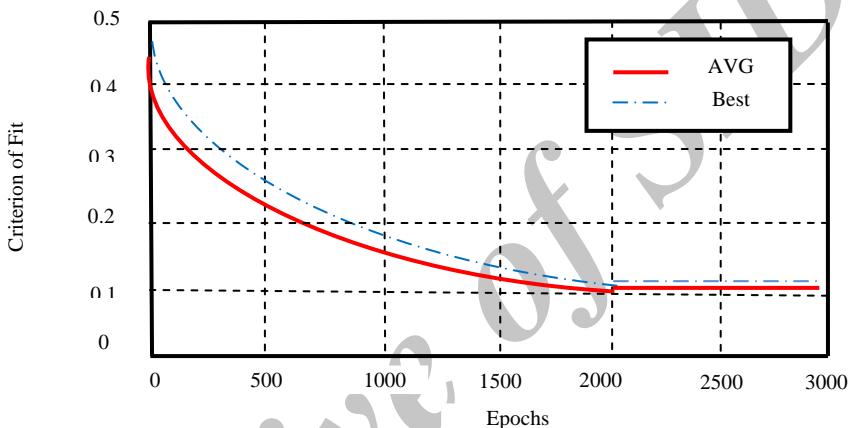
نگاره ۳) شبکه عصبی مربوط به مدل چند متغیره

در این پژوهش ۵۰ درصد از داده‌ها برای آموزش، ۲۵ درصد برای اعتبارسنجی و ۲۵ درصد برای مجموعه آزمون اختصاص یافته است. از داده‌های آموزش برای محاسبه وزن‌ها استفاده می‌شود. خطا در مجموعه داده‌های اعتبارسنجی تحت کنترل قرار می‌گیرد و طی فرایند آموزش کاهشی می‌یابد. نگاره (۴) مقادیر پارامترهای الگوریتم PSO را بعد از آموزش شبکه نشان می‌دهد.

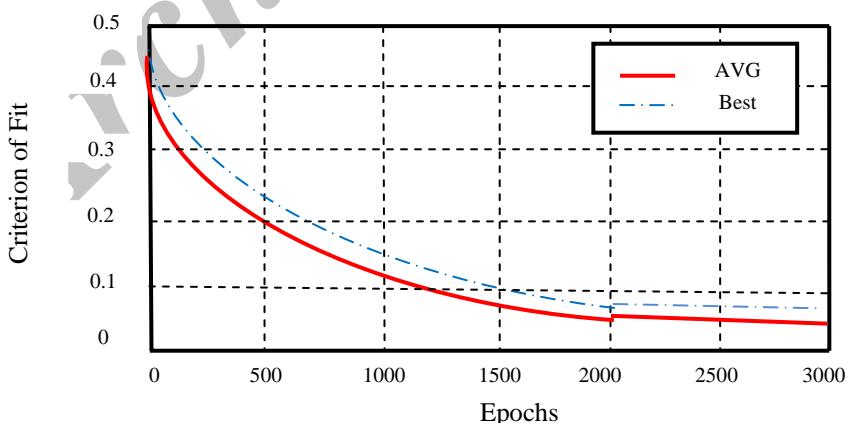
نگاره ۴ : مقدار پارامترهای محاسبه شده در الگوریتم PSO

مقدار	پارامتر
MAPE و MSE	توابع هدف
۸	ابعاد مسئله
۵۰	تعداد جمعیت
۲۰۰۰	تعداد نسل ها
۱,۳	فاکتور یادگیری
۰,۴	وزن اینرسی

نگاره‌های (۵) و (۶) فرایند آموزش را در شبکه‌های عصبی یک و چند متغیره نشان می‌دهد. همانگونه که در این نگاره‌ها مشاهده می‌شود، با افزایش تعداد تکرارها مقدار خطای کاهشی باید اما در تکرارهای پایانی تقریباً هیچ‌گونه بهبودی حاصل نمی‌شود و اصطلاحاً در این نواحی برآش بیش از حد وجود دارد. پس از آنکه بهترین ساختار شبکه‌های عصبی برای مدل‌های یک متغیره و چند متغیره تعیین گردید، سود هر سهم برای دوره آزمون یعنی از سال ۱۳۸۹ تا ۱۳۹۰، توسط هر یک از مدل‌ها پیش‌بینی می‌شود. با داشتن مقادیر پیش‌بینی شده سود هر سهم توسط مدل‌های شبکه عصبی و همچنین مقادیر واقعی سود هر سهم در این پنج سال، می‌توان خطای مدل‌ها را تعیین کرد.



نگاره ۵: روند آموزش شبکه عصبی یک متغیره



نگاره ۶: روند آموزش در شبکه عصبی چند متغیره

۶- نتایج پژوهش

پس از اینکه سود هر سهم توسط هر یک از مدل‌های فوق مورد پیش‌بینی قرار گرفت، جهت ارزیابی صحت و دقت پیش‌بینی از معیارهای MSE و MAPE استفاده می‌شود. مقادیر MSE و MAPE برای مدل‌های مذکور به شرح نگاره(۷) است. فرضیه نخست این پژوهش، در مورد توانایی الگوریتم بهینه‌سازی حرکت تجمعی ذرات جهت پیش‌بینی سود هر سهم شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران است. با توجه به اینکه نتایج به دست آمده از آزمون عملکرد مدل‌ها نشان می‌دهد که مدل یک متغیره با دقت ۷۸,۵٪ و مدل چند متغیره با دقت ۹۱,۷٪ سود هر سهم شرکت‌ها را پیش‌بینی می‌کند، از این‌رو فرضیه نخست ردنمی‌شود و می‌توان نتیجه گرفت که استفاده از الگوریتم بهینه‌سازی حرکت تجمعی ذرات جهت پیش‌بینی سود هر سهم از دقت پیش‌بینی قابل قبولی برخوردار است. فرضیه دوم پژوهش نیز در خصوص توانایی متغیرهای بنیادی حسابداری جهت افزایش دقت پیش‌بینی الگوریتم بهینه‌سازی انبوه ذرات در پیش‌بینی سود هر سهم شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران است. در این خصوص نیز با توجه به اینکه دقت پیش‌بینی مدل چند متغیره ۹۱,۷٪ و دقت پیش‌بینی مدل یک متغیره ۷۸,۵٪ است، فرضیه دوم نیز رد نخواهد شد. لذا می‌توان نتیجه گرفت که گنجاندن متغیرهای بنیادی حسابداری در مدل شبکه‌های عصبی جهت پیش‌بینی سود هر سهم، منجر به افزایش دقت پیش‌بینی آن می‌شود.

نگاره ۷ : مقدار خطای مدل‌های یک متغیره و چند متغیره

مدل های مورد استفاده (%)MAPE	مدل های مورد استفاده (%)MSE	
۲۲,۶	۱۲,۵	مدل یک متغیره
۱۸,۷	۳,۸	مدل چند متغیره

۷- نتیجه‌گیری و بحث

شبکه‌های عصبی علاوه بر ارائه پیش‌بینی‌های دقیق‌تر، مشکلات رایج مدل‌سازی کلاسیک از قبیل پایایی و نپایایی سری‌های زمانی را ندارند و از این نظر همانند مدل‌سازی کلاسیک، جهت رفع مشکلات خود همبستگی، هم خطی و ناهمسانی واریانس، نیازمند آماده‌سازی سری‌های زمانی متغیرهای مالی نیستند. عملکرد مناسب شبکه‌های عصبی در مقایسه با سایر روش‌های متداول بیانگر وجود روابط غیر-خطی بین متغیرها است.

در این پژوهش به بررسی توانایی یکی از جدیدترین روش‌های موجود در زمینه‌پیش‌بینی (الگوریتم بهینه‌سازی حرکت تجمعی ذرات) در بهینه‌سازی شبکه‌های عصبی جهت پیش‌بینی سود هر سهم شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران پرداخته شد.

بدین منظور با استفاده از ترکیب شبکه‌های عصبی و الگوریتم بهینه‌سازی حرکت تجمعی ذرات دو مدل برای پیش‌بینی سود هر سهم ارائه گردید. مدل اول یک مدل یک متغیره است که در آن سود هر سهم سال گذشته به عنوان متغیر مستقل در نظر گرفته شده است و مدل دوم یک مدل چند متغیره است که در آن بر اساس مطالعه لو و تیاگاراجان (۱۹۹۳)، علاوه بر سود هر سهم سال گذشته، از متغیرهای بنیادی حسابداری نیز به عنوان متغیر مستقل استفاده شده است.

نتایج حاصل از برآورد شبکه‌های عصبی طراحی شده نشان می‌دهد که استفاده از الگوریتم بهینه‌سازی انبوه ذرات جهت پیش‌بینی سود هر سهم شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران، از عملکرد قابل قبولی برخوردار است. یافته‌ها همچنین حاکی از آن است که استفاده از متغیرهای بنیادی حسابداری به عنوان متغیرهای مستقل در مدل‌های مربوط به پیش‌بینی سود هر سهم، منجر به افزایش قدرت پیش‌بینی آنها می‌شود.

همانگونه که در بخش پیشینه پژوهش مطرح شد، زانگ و همکاران (۲۰۰۴) جهت پیش‌بینی سود هر سهم از روش‌های آماری کلاسیک و شبکه‌های عصبی مصنوعی و کاو و پاری (۲۰۰۹) بدین منظور از شبکه‌های عصبی مصنوعی و الگوریتم ژنتیک استفاده کردند و تاکنون مطالعه‌ای جهت پیش‌بینی سود هر سهم با استفاده از الگوریتم بهینه‌سازی انبوه ذرات چه در داخل و چه در خارج از کشور انجام نشده است. لذا نتایج این پژوهش فقط با نتایج دو مطالعه فوق قابل مقایسه می‌باشد. در این راستا نتایج مطالعه حاضر در خصوص پیش‌بینی سود هر سهم با استفاده از الگوریتم بهینه‌سازی انبوه ذرات در هر دو مدل یک متغیره و چند متغیره، بهتر از نتایج بدست آمده در پژوهش‌های زانگ و همکاران (۲۰۰۴) و کاو و پاری (۲۰۰۹) می‌باشد.

فهرست منابع

- ۱) دموری داریوش، فرید داریوش، اشهر مرتضی (۱۳۹۰). پیش‌بینی شاخص کل بورس اوراق بهادار تهران با استفاده از الگوریتم پرواز پرنده‌گان و مقایسه آن با الگوهای سنتی. دانش حسابداری. دوره ۲، شماره ۵، صص ۷-۳۰.
- ۲) راعی رضا و علی‌بیکی هدایت (۱۳۸۹). بهینه‌سازی پرتفوی سهام با استفاده از روش حرکت تجمعی ذرات. تحقیقات مالی، دوره ۱۲، شماره ۲۹، صص ۴۰-۲۱.

- (۳) ستایش محمدحسین، کاظم‌نژاد مصطفی، شفیعی محمدجواد.(۱۳۸۸). کاربرد الگوریتم ژنتیک در تعیین ساختار بهینه سرمایه شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران. بررسی‌های حسابداری و حسابرسی، دوره ۱۶، شماره ۵۶، صص ۵۸-۳۹.
- (۴) عرب‌مازار محمد، قاسمی مهسا.(۱۳۸۸). قیمت‌گذاری عرضه‌های عمومی اولیه: ترکیب شبکه‌های عصبی مصنوعی و الگوریتم ژنتیک. بررسی‌های حسابداری و حسابرسی. دوره ۱۶، شماره ۵۸، صص ۸۷-۱۰۲.
- 5) Abarbanell, J.S., Bushee, B.J., (1997). Fundamental Analysis, Future EPS and Stock Prices. *Journal of Accounting Research*, 35(1): 1-24.
 - 6) Callen, J.L., Kwan, C.C.Y., Yip, P.C.Y., Yuan, Y., (1996). Neural Network Forecasting of Quarterly Accounting Earnings. *International Journal of Forecasting*, 12(4): 475-482.
 - 7) Cao, Qing, Parry Mark, E., (2009). Neural Network Earning per Share Forecasting Models: a Comparison of Backward Propagation and Genetic Algorithm. *Decision Support Systems*, 47: 32-41.
 - 8) Deng, G.F., Lin, W.T., Lo, C.C., (2012). Markowitz-Based Portfolio Selection with Cardinality Constraints Using Improved Particle Swarm Optimization. *Expert Systems with Applications*, 39: 4558-4566.
 - 9) Etemadi, H., Anvary Rostamy, A.A., Farajzadeh Dehkordi, H., (2009). A Genetic Programming Model for Bankruptcy Prediction: Empirical Evidence from Iran. *Expert Systems with Applications*, 36, 3199-3207.
 - 10) Golmakani, H.R., Fazel, M., (2011). Constrained Portfolio Selection Using Particle Swarm Optimization. *Expert Systems with Applications*, 38: 8327-8335.
 - 11) Hadavandi, E., Shavandi, H., Ghanbari, A., (2010). Integration of Genetic Fuzzy Systems and Artificial Neural Networks for Stock Price Forecasting. *Knowledge Based Systems*, 23, 800-808.
 - 12) Haykin, S., (1998). *Neural Networks: a Comprehensive Foundation*. Prentice Hall PTR, Upper Saddle River.
 - 13) Hsu, L.Y., Horng, S.J., He, M., Fan, P., Kao, T.W., Khan, M.K., Run, R.S., Lai, J.L., Chen, R.J., (2011). Mutual Funds Trading Strategy Based On Particle Swarm Optimization. *Expert Systems with Applications*, 38: 7582-7602.
 - 14) Kennedy, J., Eberhart, R.C., (1995). Particle Swarm Optimization. In Proceedings of the IEEE International Conference on Neural Networks IV.
 - 15) Lev, B., Thiagarajan, S.R., (1993). Fundamental Information Analysis. *Journal of Accounting Research*, 31(2): 190-215.
 - 16) Poli, R., Kennedy, J., Blackwell, T., (2007). Particle Swarm Optimization: an overview. *Swarm Intell*, 1: 33-57.
 - 17) Shanker, M., Hu M.Y., Hung, M.S., (1996). Effect of Data Standardization on Neural Networks Training. *Omega*, 24: 385-397.

- 18) Zhang, W., Cao, Qing, Schniederjans, M., (2004). Neural Network Earning per Share Forecasting Models: a Comparative Analysis of Alternative Methods. *Decision Sciences*, 35: 205- 237

یادداشت‌ها

- ¹- Artificial Neural Networks
- ²- Particle Swarm Optimization Algorithm
- ³- Swarm
- ⁴- Particle
- ⁵- Gbest Neighborhood Topology
- ⁶- Previous Best
- ⁷- Global Best
- ⁸- Global Search
- ⁹- Local Search
- ¹⁰- ARIMA
- ¹¹- Backward Propagation Algorithm
- ¹²- Genetic Algorithm
- ¹³- Genetic Programming
- ¹⁴- Fuzzy- Genetic Systems
- ¹⁵- Out of Sample
- ¹⁶- Rolling Estimation Method